

Un análisis no intrusivo de condiciones anómalas en motores trifásicos mediante señales de corriente y técnicas de Inteligencia Artificial

Guillermo León Zapata Álvarez, Rafael Andrade Cortegoso, José M. Bernal de Lázaro

RESUMEN / ABSTRACT

Los motores trifásicos de inducción constituyen un elemento central en numerosos procesos industriales. Este trabajo propone un enfoque de diagnóstico de fallos no invasivo para motores trifásicos de inducción que utiliza exclusivamente señales de corriente por fase. Se evalúan dos estrategias de Inteligencia Artificial: (i) un método basado en descriptores estadísticos y frecuenciales combinado con un clasificador *Random Forest*, y (ii) una Red Neuronal Convolucional con *Autoencoder* (*AE+CNN*), que modela el comportamiento saludable del motor y detecta desviaciones mediante errores de reconstrucción. El procedimiento de detección de fallos contempla la transformación y segmentación de las señales trifásicas, el análisis de características temporales y frecuenciales, el entrenamiento y validación de ambos modelos, así como la evaluación de su robustez ante distintas condiciones operativas. Los experimentos se desarrollan utilizando datos reales de una planta piloto con dos bombas centrífugas accionadas por motores de inducción y variadores de velocidad. Los resultados permiten valorar la eficacia comparativa de ambos enfoques y su potencial para una implementación práctica, económica y escalable en entornos industriales.

Palabras claves: motores trifásicos de inducción, corriente por fase, detección de fallos, *Random Forest*, *AE+CNN*

Three-phase induction motors are a key component in numerous industrial processes. This work proposes a non-invasive fault-diagnosis approach for three-phase induction motors that relies exclusively on per-phase current signals. Two Artificial Intelligence strategies are evaluated: (i) a method based on statistical and frequency-domain descriptors combined with a Random Forest classifier, and (ii) a Convolutional Neural Network with an Autoencoder (AE+CNN), which models the motor's healthy behavior and detects deviations through reconstruction errors. The fault-detection procedure includes the transformation and segmentation of the three-phase current signals, analysis of time- and frequency-domain features, training and validation of both models, and assessment of their robustness under different operating conditions. Experiments are conducted using real data from a pilot plant equipped with two centrifugal pumps driven by induction motors and variable-speed drives. The results demonstrate the comparative effectiveness of both approaches and their potential for practical, cost-efficient, and scalable implementation in industrial environments.

Key words: *three-phase induction motors, phase current signals, fault detection, Random Forest, AE+CNN*

A non-intrusive analysis of anomalous conditions in three-phase motors using current signals and Artificial Intelligence techniques

1-INTRODUCCIÓN

Debido a su elevada robustez y versatilidad para operar en diversos entornos, los motores trifásicos de inducción constituyen el núcleo de numerosos procesos industriales. Atender oportunamente los fallos eléctricos y mecánicos que tienen lugar estos motores es crucial para mantener la eficiencia operativa y evitar paradas no planificadas con alto impacto económico [1,2].

Recibido: 9/2025 Aceptado: 12/2025

Entre los fallos eléctricos más comunes se encuentran los cortocircuitos entre espiras, originados por la degradación del aislamiento y responsables de aproximadamente el 30 %–40 % de las averías en el estator. Este deterioro suele estar asociado a humedad, temperaturas elevadas y contaminación por aceite o suciedad, factores que comprometen las propiedades dieléctricas del aislamiento y favorecen los cortocircuitos. Para detectar de forma temprana este tipo de degradación, se emplean transformadores de corriente de alta sensibilidad (HSCT), capaces de medir y descomponer la corriente de fuga en sus componentes resistiva y capacitiva, proporcionando una estimación fiable del estado del aislamiento [2,3]. En cuanto a los fallos mecánicos, se originan principalmente por vibraciones, desalineaciones, tensiones de correas, y condiciones operativas inadecuadas. Por otro lado, se estima que alrededor del 70 % de las averías mecánicas en los motores están de alguna manera relacionadas al desgaste de los rodamientos, y éstos a menudo pueden desencadenar fallos secundarios en el motor como la típica rotura de las barras del rotor o el desplazamiento del rotor respecto al estator [3]. La alta incidencia y el costo asociado a los fallos eléctricos y mecánicos en los motores eléctricos justifican, por tanto, la necesidad de desarrollar enfoques de diagnóstico más eficientes, económicos y fácilmente integrables en entornos industriales [1-6]. Sin embargo, tal como se muestra en la Tabla 1, las técnicas tradicionales para la detección de tales fallos suelen requerir sensores adicionales o intervenciones en la máquina eléctrica, lo cual incrementa el costo y limita su aplicación de manera en grandes plantas industriales [7]. En este contexto, resulta especialmente atractivo entonces desarrollar soluciones basadas en señales eléctricas de la propia operación del motor. Siendo así, diversos estudios demuestran que las perturbaciones mecánicas y eléctricas se manifiestan en la señal de corriente, lo que abre la posibilidad de realizar un diagnóstico basado en una variable ampliamente disponible y de adquisición no invasiva.

Tabla 1
 Enfoques de detección de fallos en motores eléctricos utilizando las técnicas tradicionales y señales eléctricas.

	Técnicas tradicionales (vibración, temperatura, acústica)	Métodos basados en señales eléctricas (corriente, tensión, potencia)
Ventajas	<ul style="list-style-type: none"> • Muy precisas para fallos mecánicos. • Tecnologías consolidadas. • Alto nivel de madurez industrial. 	<ul style="list-style-type: none"> • No intrusivos y de bajo costo. • Usan sensores ya disponibles en tableros y SCADA. • Adecuados para monitoreo en línea. • Escalables para grandes plantas.
Desventajas	<ul style="list-style-type: none"> • Elevado costo por sensores dedicados. • Instalación intrusiva. • Necesidad de calibración y mantenimiento. • Poca escalabilidad. 	<ul style="list-style-type: none"> • Menor sensibilidad ante fallos mecánicos • Requiere procesar armónicos. • A veces insuficiente para fallas puramente mecánicas.

A partir de esto, el presente trabajo propone un enfoque de detección de fallos en motores eléctricos de jaula de ardilla donde se utiliza exclusivamente las señales de corriente por fase, medida de forma no invasiva desde la acometida del motor. Este enfoque evita la instalación de sensores o modificaciones adicionales en la máquina eléctrica, posibilitando una implementación rápida, económica y compatible con ambientes industriales reales [7, 8]. Desde la perspectiva, la solución propuesta evalúa y compara dos estrategias de Inteligencia Artificial para el diagnóstico de los fallos considerando el análisis de las señales de corriente eléctrica en el motor. El primer enfoque que es evaluado considera las variables estadísticas y las mediciones en frecuencia que caracterizan el comportamiento del motor para identificar los fallos mediante un clasificador *Random Forest*. En el segundo enfoque evaluado, se utilizan fragmentos temporales (ventanas) de la señal de corriente para aprender el patrón de operación normal mediante una Red Neuronal Convolucional con *Autoencoder* (AE+CNN), que genera señales residuales para describir desviaciones respecto al comportamiento saludable del motor. De esta manera se logran evaluar métodos basados en características explícitas y métodos basados en aprendizaje directo de la señal, respectivamente. En este sentido, *Random Forest* proporciona robustez ante ruido y una elevada capacidad para manejar conjuntos de datos multidimensionales [9]. En tanto, AE+CNN permite modelar distribuciones normales de funcionamiento detectando desviaciones respecto a la operación normal del motor a partir del error de reconstrucción, siendo particularmente útil para capturar relaciones no lineales y características ocultas en las señales de corriente [10, 11].

El objetivo general de este trabajo es evaluar la viabilidad de *Random Forest* y AE+CNN para detectar fallas operativas en motores eléctricos de jaula de ardilla, considerando exclusivamente señales de corriente. Para validar la efectividad de la propuesta se consideran condiciones representativas de los entornos industriales, pero sin depender de sensores de vibración y temperatura. Para ello se establecen cuatro pasos fundamentales: (i) transformación de señales de corriente trifásica y segmentación en ventanas temporales, (ii) análisis de descriptores en el dominio del tiempo y la frecuencia, (iii) entrenamiento y validación de los modelos de clasificación supervisada *Random Forest* y AE+CNN, y (iv) evaluación de robustez del modelo predictivo frente a diferentes condiciones operativas. La efectividad de *Random Forest* y AE+CNN se evalúa utilizando los

datos presentados por [12], y que describen la operación de dos bombas centrífugas, impulsadas por motores de inducción con variadores de velocidad.

El presente trabajo se organiza de la siguiente manera. La Sección 2 realiza una breve descripción del caso de estudio y los datos históricos utilizados. Los procedimientos con *Random Forest* y AE+CNN se abordan en la Sección 3. La Sección 4 se centra en el análisis y discusión de los resultados, enfatizando algunos aspectos relevantes del diseño experimental. Finalmente se realizan las conclusiones del trabajo y líneas futuras.

2.- CASO DE ESTUDIO Y TRANSFORMACIÓN DE DATOS

El caso de estudio utilizado en esta investigación fue presentado por Bruinsma, (2024) [12], y cuenta con datos experimentales de dos bombas centrífugas, impulsadas por motores de inducción con variadores de velocidad. La información técnica de la instalación piloto y los datos de chapa de los motores se puedes visualizar en la Fig. 1 y Tabla 2, respectivamente. El conjunto de datos obtenido de este sistema recoge las lecturas del comportamiento del estado saludable de cada motor y diez fallos simulados: (1) rodamientos defectuosos, (2) apoyos flojos, (3) impulsor averiado, (4) corto circuito del estator, (5) rotura de barra del rotor, (6) desalineamiento, (7) desbalance, (8) degradación del acoplamiento, (9) cavitación, y (10) eje doblado. Para cada tipo de fallo se recopilan datos con distintos niveles de severidad y velocidades de funcionamiento para el motor. Todas las condiciones incluyen datos de vibración, corriente y tensión.



Figura 1

Planta Piloto [12]: (1) motor, (2) bomba, (3) salida de agua, (4) entrada de agua, (5) válvula, y (6) variador de frecuencia (VFD).

Los datos de vibración son obtenidos mediante acelerómetros, y las señales eléctricas se obtienen a partir de pinzas de corriente colocadas en cada fase. La medición de las variables involucradas se realiza cada cinco minutos y se almacenan en archivos CSV. Considerando esta configuración un total de cinco archivos CSV equivalentes a cinco canales para los datos de vibración y seis archivos CSV equivalentes a seis canales para los datos eléctricos se construyen para su análisis. Cada archivo CSV contiene seis columnas, comenzando por la información temporal y seguida por la información de las variables físicas medidas.

Tabla 2

Detalles y datos de chapa de los motores eléctricos [12]

Nr.	Etiqueta Técnica	Polos	Umax(V)/Imax(A)	kW @ PRM	Rodamientos
2	MG160MA4042-H3	4	380-415/23.4-22.4	11 @ 1470	6309.C4
4	MG180MB2-48-F1	2	380-415/43.5	22 @ 2950	6310.C4

En el caso de los datos eléctricos, los seis archivos CSV contienen 300000 muestras por columna, siendo los tres primeros canales las corrientes por fase y los canales restantes la tensión por fase. Es válido destacar que, en el presente estudio, se utilizaron solamente los datos eléctricos del Motor-2 que contiene registros en diferentes velocidades de operación (50%, 75% y 100%). Asimismo, tal como se observa en la Fig. 2, el análisis experimental se ha limitado al estudio de tres fallos y el estado de operación saludable. Los fallos considerados son: (1) rotura de barras del rotor, (2) contaminación de rodamientos, y (3) cortocircuito en el estator. La detección de estos eventos anómalos se considera de suma importancia debido su alta incidencia en los motores de inducción que se utilizan en entornos industriales. A modo de ejemplo, la Fig. 2 ilustra las diferencias en las características que asume la corriente de fase para los estados de operación antes mencionados. Como se observa en la Fig. 2(a), el estado de operación saludable del motor (sin fallos), se caracteriza por una señal sinusoidal suave y simétrica. Por otro lado, como se aprecia en la Fig. 2(b), cuando existen rodamientos contaminados la señal de corriente muestra ligeras irregularidades por las vibraciones o micro-oscilaciones que se originan del desgaste y las partículas en los rodamientos. En tanto, la Fig. 2(c) muestra la señal de corriente ante el fallo en el estator cortocircuitado. En este caso la señal se caracteriza por asimetrías y desfase en la amplitud, ya que los cortocircuitos en el estator suelen generar desequilibrios magnéticos que afectan a la forma de la corriente. Por último, en la Fig. 2(d), se aprecia una modulación en la envolvente con variaciones cíclicas en la amplitud que son típicas del fenómeno conocido como frecuencia de deslizamiento que ocurre debido a la rotura de barras del rotor. Para realizar el estudio con los datos de este caso de estudio, los conjuntos de entrenamiento (60%), prueba (20%) y validación (20%) se generan utilizando una semilla aleatoria que garantiza no caer en sesgos por secuencia o posición dentro del data set. Además, se implementó un enfoque de validación externa para el modelo predictivo considerando la disponibilidad de datos de operación normal en tres diferentes condiciones operativas (saludable1, saludable2 y saludable3). Esta metodología permite evaluar la capacidad de generalización del modelo predictivo teniendo en cuenta registros de operación sin fallos que son obtenidos bajo diversas configuraciones de acoplamiento entre el motor y la bomba. Esta estrategia de selección aleatoria se fundamenta en el supuesto de que los datos representan muestras independientes e idénticamente distribuidas. Este supuesto es común en problemas de aprendizaje automático y análisis de series temporales estacionarias, donde se considera que los datos provienen de una misma distribución y no están correlacionados entre sí de forma significativa [13], y resulta válido siempre que se garanticen condiciones operativas constantes durante la adquisición, así como la independencia temporal entre las columnas consecutivas del conjunto de datos históricos. Las distintas configuraciones para el estado saludable (ejemplo, saludable 1 vs. saludable 2) permiten emular condiciones reales de variabilidad estructural del sistema, alineándose con el concepto de validación externa (*out-of-distribution testing*) [14].

2.1 SEGMENTACIÓN TEMPORAL EN VENTANAS

La segmentación temporal de los datos brutos contenidos en los conjuntos de entrenamiento, prueba y validación se realiza para transformar las señales de corriente en unidades de análisis compatibles que serán las entradas a los modelos de aprendizaje automático utilizados. En el caso del modelo *Random Forest*, las señales fueron divididas en ventanas de 1 segundo de duración, lo que equivale a 20.000 muestras por ventana, dada la frecuencia de muestreo del sistema de 20 kHz. Este tamaño de ventana provee un equilibrio entre resolución temporal y riqueza espectral que permite capturar múltiples ciclos de la señal, facilitando la identificación de armónicos, distorsiones y transitorios relevantes para la clasificación de los fallos. Por otro lado, en AE+CNN se optó por un enfoque de mayor granularidad utilizando ventanas de 25 microsegundos, correspondientes a 500 muestras por segmento. A diferencia del modelo *Random Forest*, el uso de ventanas más pequeñas para el AE+CNN permiten captar variaciones locales más sutiles en el comportamiento normal del motor. En ambos casos, las ventanas fueron generadas sin solapamiento para evitar la dependencia entre muestras consecutivas, y preservar la integridad del proceso de evaluación. Al no incluir solapamiento entre ventanas se evitan muestras demasiado similares, lo cual podría inducir fenómenos de sobreajuste y comprometer la generalización del modelo. Esta precaución está respaldada por estudios como el de Bengio (2013) [15], quienes advierten sobre los riesgos de dependencia entre instancias en modelos de representación profunda. Esta estrategia de segmentación diferenciada permite adaptar el formato de entrada a las necesidades específicas de cada arquitectura, optimizando tanto la extracción de características como el aprendizaje de patrones relevantes en los datos. El proceso de segmentación para *Random Forest* generó unas 2.025 ventanas para entrenamiento, 675 ventanas para prueba, y 540 ventanas para validación. En el caso de AE+CNN, se obtuvieron 81.000 ventanas para entrenamiento, 27.000 ventanas para prueba, y 21.600 ventanas para la etapa de validación.

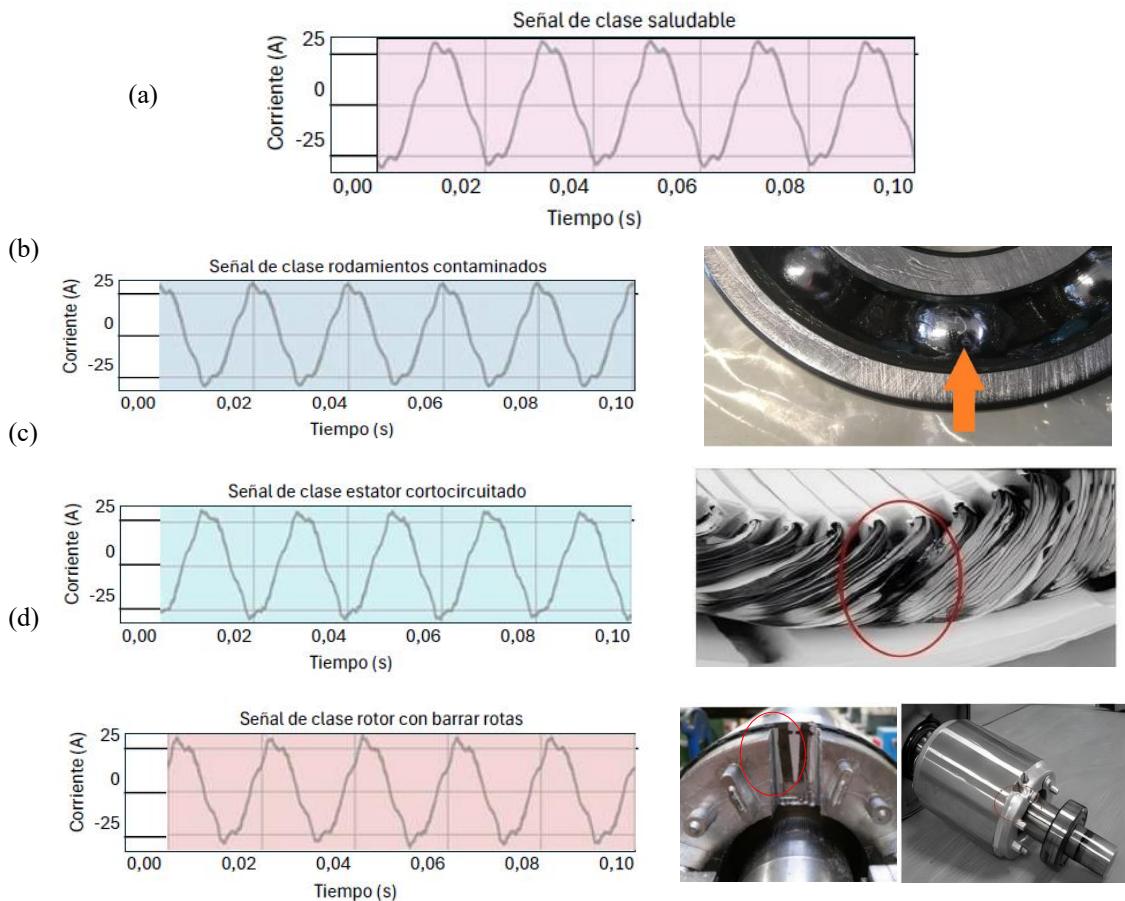


Figura 2

Operación del motor [12]: (a) saludable, (b) contaminación de rodamientos, (c) cortocircuito en estator, y (d) rotura de barras.

2.2 CARACTERÍSTICAS EN EL DOMINIO DEL TIEMPO Y FRECUENCIA

Para extraer características combinadas en el dominio del tiempo y la frecuencia se consideraron métricas estadísticas como la media, el valor absoluto medio, la raíz cuadrada media (RMS), la desviación estándar, la curtosis, la asimetría y los valores máximos y mínimos. Las características en frecuencia se obtuvieron mediante la Transformada Rápida de Fourier (FFT), dividiendo el espectro en bandas de 100 Hz y calculando en cada una de ellas la frecuencia dominante, la magnitud máxima, la magnitud media y la desviación estándar. También se consideraron las características en el dominio de la frecuencia, pero omitiendo por completo las métricas del dominio temporal. Esta variante permite evaluar si las componentes espectrales por sí solas contienen suficiente información discriminativa para el diagnóstico de las fallas, además de explorar la posibilidad de reducir la dimensionalidad del espacio de características y simplificar el flujo de procesamiento sin sacrificar el rendimiento predictivo, como se muestra en la Tabla 3.

Tabla 3
 Comparación de enfoques de extracción de características.

Enfoque	Descripción	Tipo de características	Objetivo principal
Tiempo + frecuencia	Extrae características estadísticas del dominio temporal y espectrales por bandas en el dominio de la frecuencia.	Media, RMS, curtosis, skewness + FFT por bandas	Capturar máxima información de forma complementaria.
Solo frecuencia	Extrae únicamente características espectrales por bandas aplicando la FFT.	FFT: frecuencia dominante, magnitudes por banda	Evaluar la capacidad discriminativa de componentes espectrales

3.- PROCEDIMIENTOS CON RANDOM FOREST / AE+CNN

3.1 Principios de operación del clasificador Random Forest

Random Forest es un algoritmo de *bagging* que combina un conjunto de árboles de decisión, cada uno entrenado sobre una muestra aleatoria obtenida mediante *bootstrap*, lo que permite mejorar la estabilidad y precisión del modelo. En cada nodo, la división se realiza considerando un subconjunto aleatorio de características que reduce la correlación entre árboles y promueve la diversidad estructural. Para clasificación, la predicción final se obtiene mediante votación mayoritaria. El algoritmo reduce la varianza del estimador respecto a una sola estructura arbórea sin aumentar excesivamente el sesgo, dado que la combinación de clasificadores débiles no correlacionados permite aproximar la función objetivo con menor error generalizado. La importancia de las características suele estimarse mediante la disminución media del índice Gini, lo que proporciona información sobre la contribución relativa de cada variable al modelo. En conjunto, *Random Forest* constituye un estimador robusto, no paramétrico y altamente paralelo, adecuado para datos heterogéneos y escenarios con ruido o interacciones complejas entre variables.

3.2 Principios de operación del clasificador AE+CNN

El modelo AE+CNN combina un *Autoencoder* no supervisado con una red convolucional para la extracción jerárquica de características y clasificación. El *Autoencoder* se compone de un codificador $f_\theta: X \rightarrow Z$ que mapea los datos de entrada $x \in \mathbb{R}^n$ a un espacio latente $z \in \mathbb{R}^m$ $m \ll n$, y un decodificador $g_\theta: Z \rightarrow X$ que reconstruye la entrada $\hat{x} = g_\theta(f_\theta(x))$, minimizando la función de reconstrucción $\mathcal{L}_{rec} = \|x - \hat{x}\|^2$. La representación latente z es posteriormente alimentada a una red neuronal que aplica las operaciones de convolución y *pooling* para extraer patrones espaciales o temporales complejos, seguido de capas totalmente conectadas y una función de activación *softmax* para clasificación. La combinación AE+CNN permite que la red aprenda representaciones latentes compactas y eliminando ruido en los datos y optimizando simultáneamente la reconstrucción y la capacidad de discriminación supervisada, lo que conlleva a obtener un modelo robusto para detección de anomalías, clasificación de fallos y análisis de señales de alta dimensión.

3.3 Implementación de las técnicas de inteligencia computacional

Una vez se cuenta con las características de tiempo y frecuencia que describen el estado operativo del motor, se pasa al entrenamiento y validación de los modelos *Random Forest* y AE+CNN. Como primer paso, se procede a la normalización de las matrices de características a fin de evitar diferencias de escala entre variables que afecten negativamente el desempeño de los predictores. Posterior a esto, se codifican numéricamente las etiquetas de clase a través de *LabelEncoder*, y se aplica *One-Hot Encoding* para la clasificación multiclase con salidas probabilísticas, garantizando la compatibilidad *softmax*. Cabe destacar que las métricas utilizadas para validar el desempeño de ambos modelos predictivos se obtienen a partir de la matriz de confusión y los informes de clasificación por clase, siendo muy relevantes las métricas de exactitud global y puntaje macro de F1-score.

Las Figs. 3 y 4 ilustran el flujo de trabajo seguido en la implementación de los modelos *Random Forest* y AE+CNN, respectivamente.

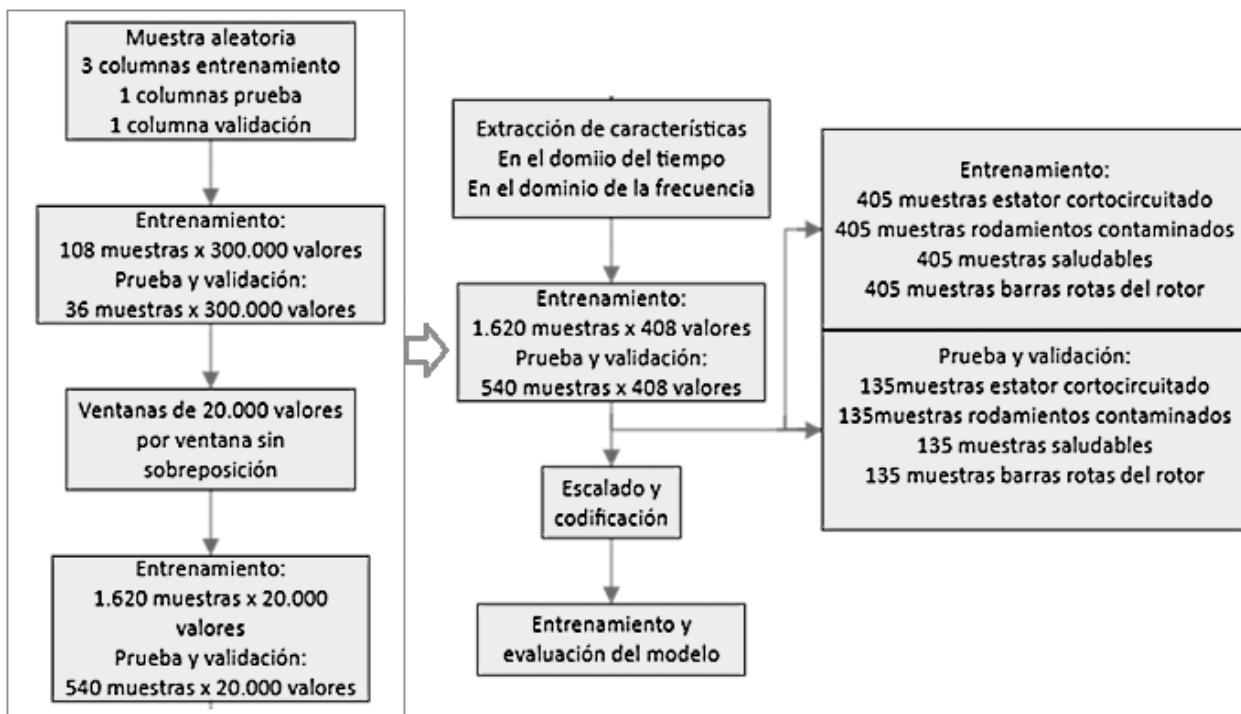


Figura 3
 Flujo de trabajo seguido en la implementación del modelo *Random Forest*

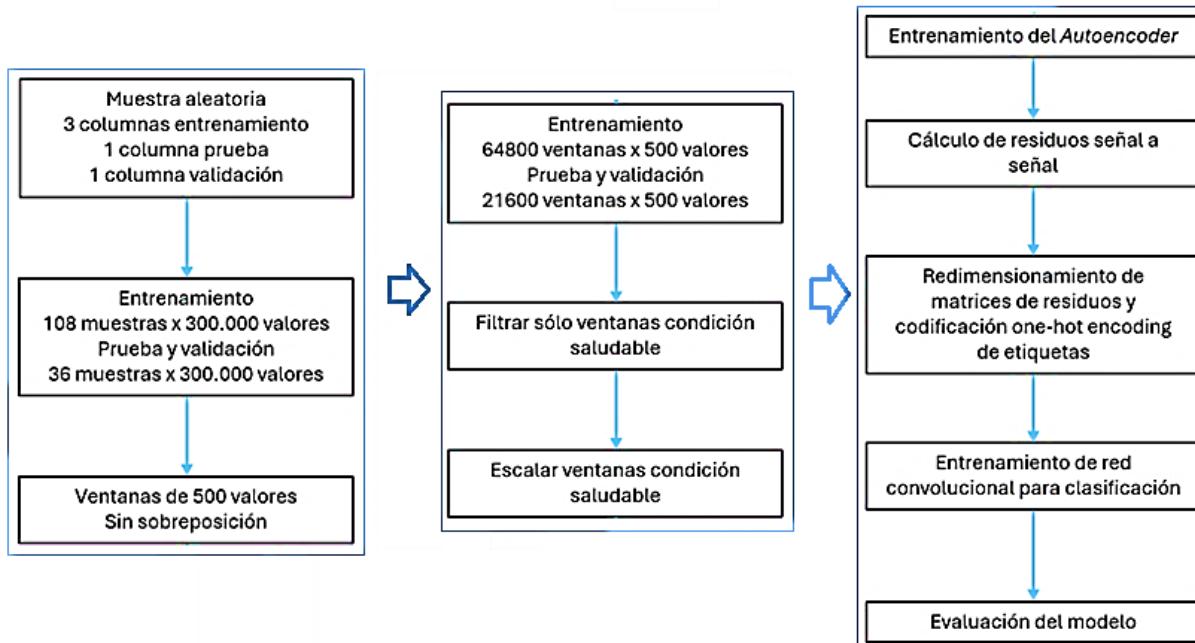


Figura 4
 Flujo de trabajo seguido en la implementación del modelo AE+CNN.

En el caso del modelo *Random Forest* el entrenamiento se realizó a partir de las características previamente extraídas de las señales, considerando conjuntamente el dominio del tiempo y frecuencia. En este sentido, *Random Forest* es particularmente útil puesto que permite trabajar directamente sobre las características extraídas, incluso cuando estas tienen escalas diferentes o presentan colinealidad parcial. Esto reduce significativamente la necesidad de preprocesamiento y lo vuelve más robusto a cambios inesperados en las condiciones del sistema. Además, su estructura basada en múltiples árboles independientes le permite procesar eficientemente el ruido y los valores atípicos, dos elementos que son frecuentes en señales eléctricas reales capturadas en entornos industriales. Los árboles individuales que componen el bosque no están fuertemente influenciados por valores extremos, ya que el impacto de estos se diluye al agregarse las predicciones en conjunto. Esta capacidad de generalización también se ha observado empíricamente en los experimentos realizados, donde se ha logrado mantener una alta precisión en los conjuntos de prueba sin incurrir en un sobreajuste significativo. Cabe destacar que para el modelo *Random Forest* se implementó la búsqueda aleatoria de los hiperparámetros intentando minimizar la diferencia del error obtenido para las etapas de entrenamiento y prueba (*overfitting gap* ≤ 0.05). Este proceso se realiza de manera iterativa evaluando las variables con mayor poder predictivo, el número de árboles, la profundidad máxima, el mínimo de muestras por hoja y por división.

En el caso de AE+CNN, tal cual se ha mencionado anteriormente, se intenta reconstruir las señales correspondientes exclusivamente al estado saludable del motor eléctrico. La hipótesis considerada en este caso parte del supuesto de que se obtendrán errores de reconstrucción elevados al identificarse señales asociadas a fallas. Acorde con la investigación de Tomas, (2021) [16], este procedimiento permite considerar el error o residuo de reconstrucción como un indicador de anomalías. Siendo así, la fase de *Autoencoder* permite aprender la representación de señales normales, y la CNN clasifica estas representaciones codificadas en diferentes tipos de fallos. Con esta filosofía de trabajo se implementó una arquitectura de *Autoencoder* completamente densa (*fully connected*) y simétrica, compuesta por capas ocultas de 1024, 512, 256, 128 y 64 neuronas en el codificador, todas con funciones de activación ReLU. Por otro lado, la representación comprimida o cuello de botella (*bottleneck*) se define como una capa densa de 64 unidades encargada de capturar las características latentes esenciales en la operación saludable del motor. En la etapa de decodificación, se replicó la estructura en sentido inverso con las mismas dimensiones, finalizando en una capa de salida lineal del mismo tamaño que la entrada (500), permitiendo reconstruir la señal original. El modelo fue compilado utilizando el optimizador Adam y la función de pérdida *Mean Squared Error* (MSE). El proceso de entrenamiento se controló mediante el enfoque de *Early Stopping*, considerando 50 épocas y la función de pérdida sobre el subconjunto de validación. Una vez finalizado el entrenamiento, el *Autoencoder* permite reconstruir las señales que describen el estado operativo del motor. Lo cual permite calcular los valores residuos considerando la diferencia punto a punto entre la señal original y su reconstrucción, que representan la entrada para la posterior etapa de clasificación supervisada. La Red Neuronal Convolucional (CNN), que forma parte del modelo discriminante, se entrena utilizando los vectores de residuo generados por el *Autoencoder*. En el clasificador neuronal se incluyó una capa Conv1D con *kernel size* de 5, activación ReLU, y una capa de *batch normalization* para estabilizar el proceso de entrenamiento. Tras cada convolución se aplicó *Max Pooling* para reducir la dimensionalidad y extraer las características más representativas, seguido de una capa *Dropout* con tasa de 0.3 para prevenir el sobreajuste. Por otro lado, la red incorpora filtros progresivamente, comenzando con 64 y aumentando hasta 512, lo que permite a la arquitectura detectar patrones complejos y jerárquicos dentro de la señal. La arquitectura neuronal implementada también incluye una capa de *Global Average Pooling* que convierte cada mapa de activación convolucional en un único valor promedio. Esta capa reduce drásticamente el número de parámetros, y también actúa como una forma de regularización estructural al enfocarse en la información global más robusta de cada canal, descartando detalles locales ruidosos. A continuación, se añade una capa densa de 128 neuronas con activación ReLU, encargada de integrar las características extraídas y preparar la información para la clasificación. Finalmente, una capa de salida con activación *softmax* devuelve una distribución de probabilidad sobre las clases posibles, permitiendo identificar el tipo de condición operativa de cada ventana de señal.

4.- ANÁLISIS Y DISCUSIÓN DE RESULTADOS

A fin de validar el desempeño de los algoritmos *Random Forest* y AE+CNN, se consideró un total de cuatro escenarios que describen la operación sin fallos (Saludable 1, Saludable 2, Saludable 3, y Saludable 4) del motor según la configuración de acoplamiento entre el motor y la bomba. Los datos adquiridos en operación con fallo: (1) rotura de barras del rotor, (2) contaminación de rodamientos, (3) cortocircuito en el estator, y los datos de operación normal del motor procedentes de las distintas configuraciones de acoplamiento se combinan para formar los escenarios descritos en la Tabla 4. A continuación, se analizan brevemente los resultados alcanzados en cada uno de estos escenarios.

Tabla 4

Escenarios experimentales considerando la operación normal con diferentes regímenes de trabajo para motor-bomba.

Escenario	Entrenamiento	Prueba	Validación
Escenario 1	Saludable 1/ Fallos	Saludable 1/ Fallos	Saludable 1/ Fallos
Escenario 2	Saludable 1/ Fallos	Saludable 1/ Fallos	Saludable 2/ Fallos
Escenario 3	Saludable 1/ Fallos	Saludable 3/ Fallos	Saludable 2/ Fallos
Escenario 4	Saludable 2/ Fallos	Saludable 3/ Fallos	Saludable 1/ Fallos

4.1 RESULTADOS ALCANZADOS PARA EL ESCENARIO 1

Las Tablas 5 y 6 resumen los resultados alcanzados por *Random Forest* y *AE+CNN* en el primer escenario. En ambos casos se está considerando las etapas de entrenamiento, prueba, y validación. Además, la comparación se realiza con base en las métricas de Precisión, Sensibilidad y Puntaje de F1-score. En el caso de *Random Forest*, la Tabla 5 ilustra que se alcanza una predicción perfecta durante la etapa del entrenamiento, aunque el desempeño global decae hasta un 5% en las etapas de prueba y validación debido que el clasificador confunde los patrones de operación normal con la operación del motor cuando existen rodamientos contaminados. La Tabla 6 confirma que el modelo *AE+CNN* también aprende acertadamente los patrones de fallos relacionados con la rotura de la barra de rotor y cortocircuito en estator. Sin embargo, respecto al clasificador *Random Forest*, la predicción utilizando *AE+CNN* decae significativamente en las etapas de prueba y validación al confundir patrones de operación normal y operación con rodamientos contaminados. La Fig. 5 utiliza la perspectiva de la matriz de confusión para ilustrar cómo *Random Forest* y *AE+CNN* se manejan durante el reconocimiento de los patrones asociados estos dos estados de operación considerando las etapas de prueba y validación.

Tabla 5

Desempeño alcanzado (%) por *Random Forest* en el Escenario 1

Estado de operación del motor	Precisión (Entrenamiento / Prueba / Validación)	Sensibilidad (Entrenamiento / Prueba / Validación)	Puntuaje F1 (Entrenamiento / Prueba / Validación)	Soporte (Entrenamiento / Prueba / Validación)
Barra de rotor rota	1.00 / 1.00 / 1.00	1.00 / 1.00 / 1.00	1.00 / 1.00 / 1.00	405 / 135 / 135
Cortocircuito en estator	1.00 / 1.00 / 1.00	1.00 / 1.00 / 1.00	1.00 / 1.00 / 1.00	405/135/135
Rodamientos contaminados	0.99 / 0.83 / 0.86	1.00 / 0.98 / 0.96	1.00 / 0.89 / 0.90	405/135/135
Saludable	1.00 / 0.97 / 0.96	0.99 / 0.80 / 0.84	1.00 / 0.88 / 0.89	405/135/135
<i>accuracy</i>	-	-	1.00 / 0.94 / 0.95	1620/540/540
<i>weighted avg</i>	1.00 / 0.95 / 0.95	1.00 / 0.94 / 0.95	1.00 / 0.94 / 0.95	1620/540/540

Tabla 6

Desempeño alcanzado (%) por *AE+CNN* en el Escenario 1

Clase	Precisión (Entrenamiento / Prueba / Validación)	Sensibilidad (Entrenamiento / Prueba / Validación)	Puntuaje F1 (Entrenamiento / Prueba / Validación)	Soporte (Entrenamiento / Prueba / Validación)
Barra de rotor rota	1.00 / 1.00 / 1.00	1.00 / 1.00 / 1.00	1.00 / 1.00 / 1.00	16200 / 5400 / 5400
Cortocircuito en estator	1.00 / 1.00 / 1.00	1.00 / 1.00 / 1.00	1.00 / 1.00 / 1.00	16200 / 5400 / 5400
Rodamientos contaminados	0.82 / 0.64 / 0.69	0.77 / 0.67 / 0.69	0.80 / 0.66 / 0.69	16200 / 5400 / 5400
Saludable	0.79 / 0.66 / 0.69	0.84 / 0.63 / 0.69	0.81 / 0.64 / 0.69	16200 / 5400 / 5400
<i>accuracy</i>	-	-	0.90 / 0.82 / 0.84	64800 / 21600 / 21600
<i>weighted avg</i>	0.90 / 0.82 / 0.84	0.90 / 0.82 / 0.84	0.90 / 0.82 / 0.84	64800 / 21600 / 21600

(a)

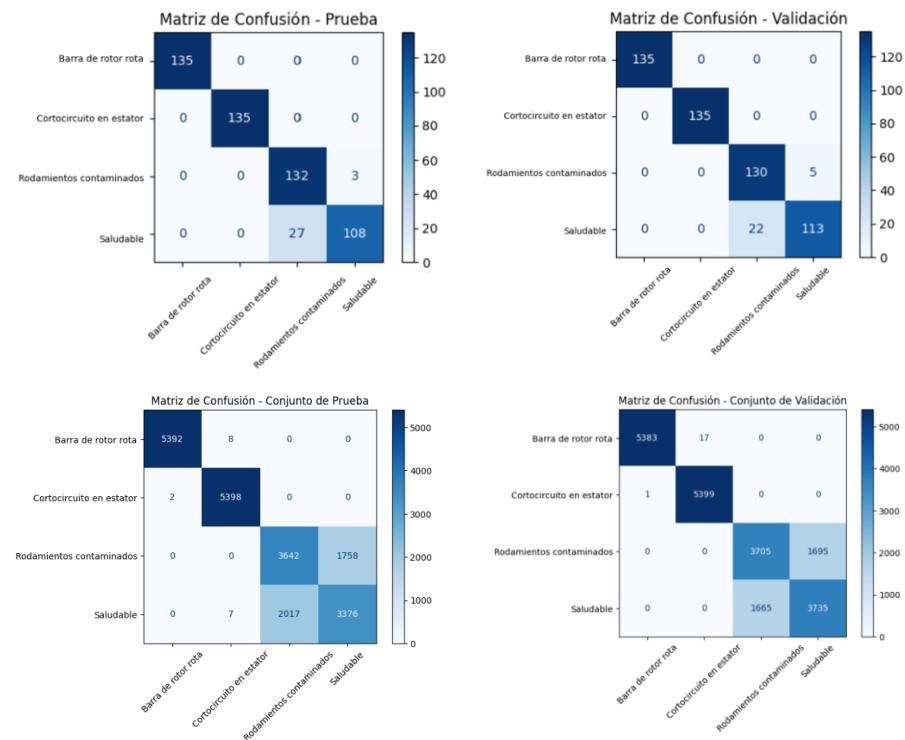


Figura 5

Matrices de confusión para etapas de prueba y validación obtenidas en el escenario 1: (a) *Random Forest*, (b) AE+CNN.

4.2 RESULTADOS ALCANZADOS PARA EL ESCENARIO 2

Los resultados obtenidos por *Random Forest* y AE+CNN en el segundo escenario se ilustran en las Tablas 7 y 8. Como en el caso anterior, se consideran las etapas de entrenamiento, prueba, y validación. La comparación también se realiza con base en las métricas de Precisión, Sensibilidad y Puntaje de F1-score. La Tabla 7 muestra que en el caso de *Random Forest* se mantienen desempeños alentadores en las etapas de entrenamiento y prueba. Sin embargo, en la etapa de validación, se observa que *Random Forest* disminuye significativamente su rendimiento y muestra una respuesta altamente sensible a cambios en el reglaje del motor indicando numerosas falsas alarmas para los fallos de cortocircuito y barra rota. Por otro lado, la Tabla 8 confirma que el modelo AE+CNN no logra identificar correctamente la condición de operación saludable, clasificando todos datos de operación normal erróneamente como fallos. Esto evidencia que el modelo AE+CNN se enfoca demasiado en la representación aprendida para operación saludable y no logra capturar totalmente la variabilidad en los datos. Por demás, diferenciar entre el estado de operación saludable y el estado de operación con rodamientos contaminados sigue siendo el mayor desafío para el modelo predictor. Este fenómeno se evidencia en la Fig. 6 que ilustra las matrices de confusión obtenidas para *Random Forest* y AE+CNN durante el reconocimiento de los patrones en las etapas de prueba y validación.

Tabla 7
 Desempeño alcanzado (%) por *Random Forest* en el Escenario 2

Estado de operación del motor	Precisión (Entrenamiento / Prueba / Validación)	Sensibilidad (Entrenamiento / Prueba / Validación)	Puntuaje F1 (Entrenamiento / Prueba / Validación)	Soporte (Entrenamiento / Prueba / Validación)
Barra de rotor rota	1.00 / 1.00 / 0.71	1.00 / 1.00 / 1.00	1.00 / 1.00 / 0.83	405 / 135 / 135
Cortocircuito en estator	1.00 / 1.00 / 0.62	1.00 / 1.00 / 1.00	1.00 / 1.00 / 0.77	405/135/135
Rodamientos contaminados	0.99 / 0.91 / 1.00	1.00 / 0.98 / 0.96	0.99 / 0.94 / 0.98	405/135/135
Saludable	1.00 / 0.98 / 0.00	0.99 / 0.90 / 0.00	0.99 / 0.94 / 0.00	405/135/135
<i>accuracy</i>	-	-	1.00 / 0.97 / 0.74	1620/540/540
<i>weighted avg</i>	1.00 / 0.97 / 0.59	1.00 / 0.97 / 0.74	1.00 / 0.97 / 0.64	1620/540/540

Tabla 8
 Desempeño alcanzado (%) por AE+CNN en el Escenario 2

Clase	Precisión (Entrenamiento / Prueba / Validación)	Sensibilidad (Entrenamiento / Prueba / Validación)	Puntuaje F1 (Entrenamiento / Prueba / Validación)	Soporte (Entrenamiento / Prueba / Validación)
Barra de rotor rota	0.99 / 0.99 / 0.99	1.00 / 1.00 / 1.00	1.00 / 1.00 / 0.99	16200 / 5400 / 5400
Cortocircuito en estator	1.00 / 1.00 / 0.50	0.99 / 0.99 / 0.99	1.00 / 1.00 / 0.67	16200 / 5400 / 5400
Rodamientos contaminados	0.73 / 0.67 / 1.00	0.88 / 0.82 / 0.81	0.80 / 0.74 / 0.89	16200 / 5400 / 5400
Saludable	0.85 / 0.77 / 0.00	0.68 / 0.59 / 0.00	0.75 / 0.67 / 0.00	16200 / 5400 / 5400
<i>accuracy</i>	-	-	0.89 / 0.85 / 0.70	64800 / 21600 / 21600
<i>weighted avg</i>	0.89 / 0.86 / 0.62	0.89 / 0.85 / 0.70	0.89 / 0.85 / 0.64	64800 / 21600 / 21600

4.3 RESULTADOS ALCANZADOS PARA EL ESCENARIO 3

En este escenario los conjuntos de datos de operación normal utilizados en entrenamiento, prueba y test son todos diferentes. Según la Tabla 4, estos datos caracterizan la operación saludable del motor en diferentes configuraciones o regímenes entre el motor y la bomba. A diferencia del segundo escenario, el desempeño de *Random Forest* y AE+CNN decaen juntos para las etapas de prueba, y validación. Tal como se aprecia en las Tablas 9 y 10, existe una elevada sensibilidad a los cambios en el reglaje del motor que se traduce en numerosas falsas alarmas, en este caso asociadas a los fallos de cortocircuito y rodamientos. La Tabla 9 muestra que el modelo AE+CNN no alcanza un desempeño superior respecto a *Random Forest*, excepto en el aislamiento del fallo relacionado a barra rota. La Fig. 7 ilustra y compara la matriz de confusión de *Random Forest* y AE+CNN considerando las etapas de prueba y validación.

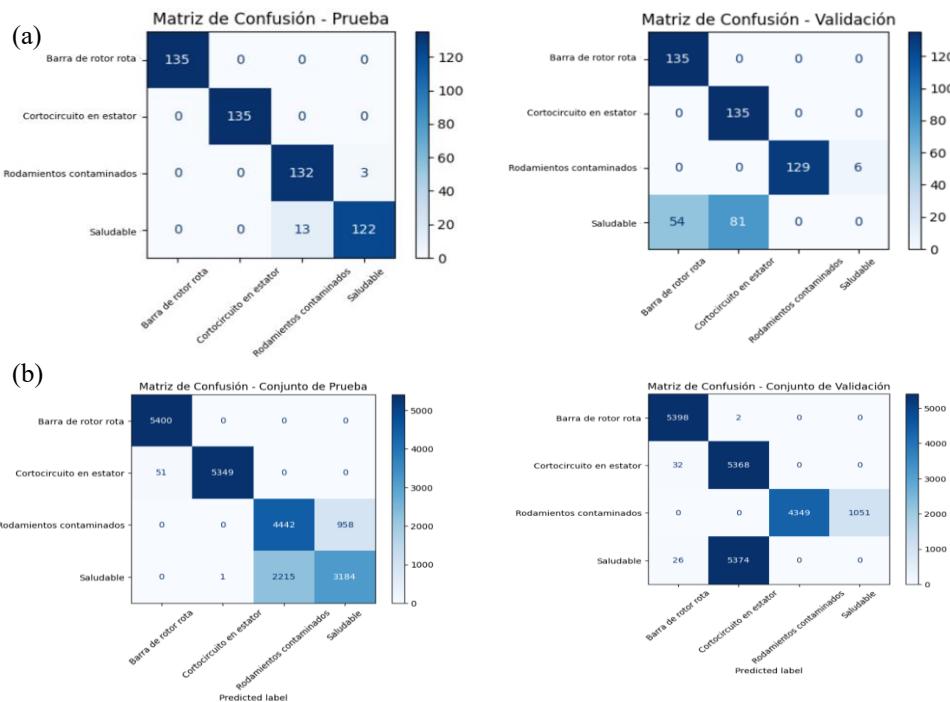


Figura 6

Matrices de confusión para etapas de prueba y validación obtenidas en el escenario 2: (a) *Random Forest*, (b) *AE+CNN*.

Tabla 9
 Desempeño alcanzado (%) por *Random Forest* en el Escenario 3

Estado de operación del motor	Precisión (Entrenamiento / Prueba / Validación)	Sensibilidad (Entrenamiento / Prueba / Validación)	Puntuaje F1 (Entrenamiento / Prueba / Validación)	Soporte (Entrenamiento / Prueba / Validación)
Barra de rotor rota	1.00 / 1.00 / 0.72	1.00 / 1.00 / 1.00	1.00 / 1.00 / 0.84	405 / 135 / 135
Cortocircuito en estator	1.00 / 1.00 / 0.62	1.00 / 1.00 / 1.00	1.00 / 1.00 / 0.77	405/135/135
Rodamientos contaminados	1.00 / 0.98 / 1.00	1.00 / 0.75 / 0.73	1.00 / 0.85 / 0.85	405/135/135
Saludable	1.00 / 0.89 / 0.00	1.00 / 0.99 / 0.00	1.00 / 0.94 / 0.00	405/135/135
<i>accuracy</i>	-	-	1.00 / 0.95 / 0.68	1620/540/540
<i>weighted avg</i>	1.00 / 0.95 / 0.59	1.00 / 0.95 / 0.68	1.00 / 0.94 / 0.61	1620/540/540

Tabla 10
 Desempeño alcanzado (%) por *AE+CNN* en el Escenario 3

Clase	Precisión (Entrenamiento / Prueba / Validación)	Sensibilidad (Entrenamiento / Prueba / Validación)	Puntuaje F1 (Entrenamiento / Prueba / Validación)	Soporte (Entrenamiento / Prueba / Validación)
Barra de rotor rota	1.00 / 0.99 / 1.00	1.00 / 1.00 / 1.00	1.00 / 1.00 / 1.00	16200 / 5400 / 5400
Cortocircuito en estator	1.00 / 1.00 / 0.50	1.00 / 0.99 / 1.00	1.00 / 1.00 / 0.67	16200 / 5400 / 5400
Rodamientos contaminados	0.70 / 0.53 / 1.00	0.63 / 0.47 / 0.51	0.66 / 0.50 / 0.68	16200 / 5400 / 5400
Saludable	0.82 / 0.75 / 0,00	0.86 / 0.79 / 0.00	0.84 / 0.77 / 0.00	32400 / 10800 / 5400
<i>accuracy</i>	-	-	0.87 / 0.81 / 0.63	81000 / 27000 / 21600
<i>weighted avg</i>	0.88 / 0.82 / 0.62	0.87 / 0.81 / 0.63	0.88 / 0.81 / 0.58	81000 / 27000 / 21600

4.4 RESULTADOS ALCANZADOS PARA EL ESCENARIO 4

Los resultados obtenidos por *Random Forest* y *AE+CNN* en el cuarto escenario experimental se ilustran en las Tablas 11 y 12. Como en el caso anterior, se tiene en cuenta la información en mostrada en el Tabla 3 para realizar la partición de los datos disponible en las etapas de entrenamiento, prueba, y validación. La comparación también se realiza con base en las métricas de Precisión, Sensibilidad y Puntaje de F1-score. Los resultados derivados de esta configuración muestran que el desempeño de *Random Forest* y *AE+CNN* decae en las etapas de validación. No obstante, *Random Forest* alcanza un desempeño global que es superior respecto a *AE+CNN*. La Tabla 11 confirma que el modelo *Random Forest* aprende acertadamente los patrones de fallos relacionados con la rotura de la barra de rotor y cortocircuito en estator, pero confunde la operación saludable con los patrones asociados a rodamientos contaminados. La Tabla 12 muestra que *AE+CNN* tiende a confundir patrones de operación saludable con los estados de fallos por cortocircuito en estator y rodamientos contaminados. La Fig. 8 utiliza la perspectiva de la matriz de confusión para ilustrar cómo *Random Forest* y *AE+CNN* se manejan durante el reconocimiento de los patrones asociados estos estos estados de operación considerando las etapas de prueba y validación. En ambos clasificadores, se evidencia un desempeño superior al observado en el segundo y tercer escenario. Sin embargo, el rendimiento alcanzado por *Random Forest* y *AE+CNN* continúa siendo inferior al obtenido como línea de comparación en el primer escenario.

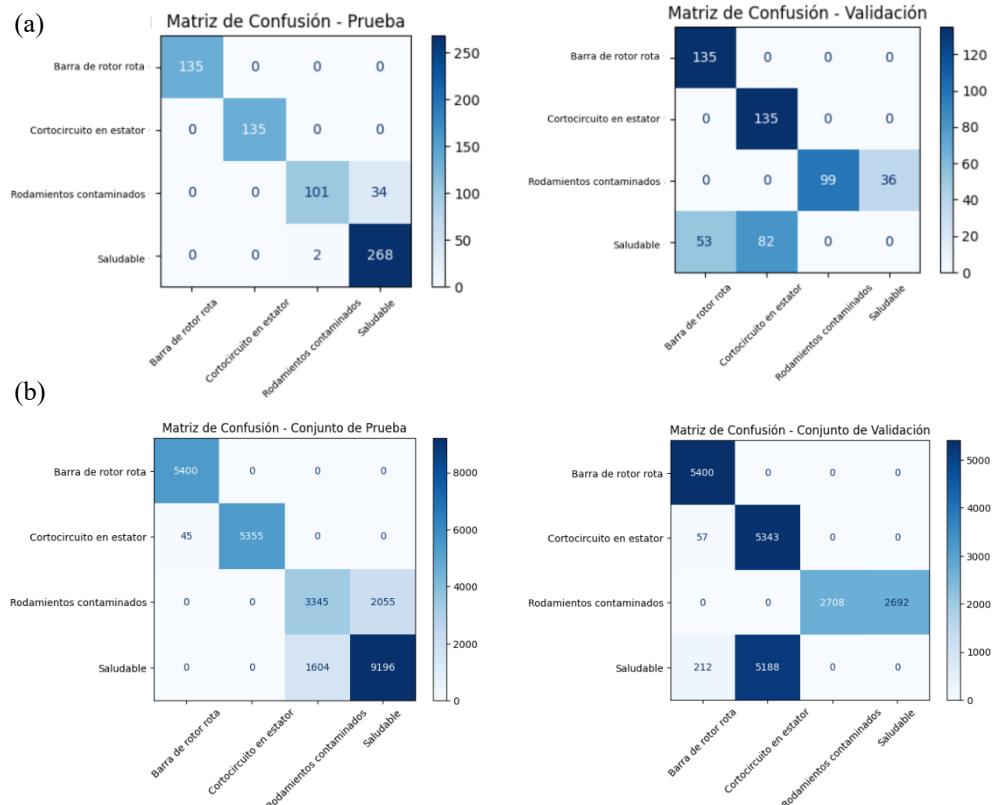


Figura 7

Matrices de confusión para etapas de prueba y validación obtenidas en el escenario 3: (a) *Random Forest*, (b) *AE+CNN*.

Tabla 11
 Desempeño alcanzado (%) por *Random Forest* en el Escenario 4

Estado de operación del motor	Precisión (Entrenamiento / Prueba / Validación)	Sensibilidad (Entrenamiento / Prueba / Validación)	Puntuaje F1 (Entrenamiento / Prueba / Validación)	Soporte (Entrenamiento / Prueba / Validación)
Barra de rotor rota	1.00 / 1.00 / 1.00	1.00 / 1.00 / 1.00	1.00 / 1.00 / 1.00	405 / 135 / 135
Cortocircuito en estator	1.00 / 0.99 / 1.00	1.00 / 1.00 / 1.00	1.00 / 1.00 / 1.00	405/135/135
Rodamientos contaminados	1.00 / 0.95 / 0.61	1.00 / 0.96 / 0.93	1.00 / 0.96 / 0.73	405/135/135
Saludable	1.00 / 0.98 / 0.85	1.00 / 0.97 / 0.39	1.00 / 0.98 / 0.54	405/135/135
<i>accuracy</i>	-	-	1.00 / 0.98 / 0.83	1620/540/540
<i>weighted avg</i>	1.00 / 0.98 / 0.87	1.00 / 0.98 / 0.83	1.00 / 0.98 / 0.82	1620/540/540

Tabla 12
 Desempeño alcanzado (%) por AE+CNN en el Escenario 4

Clase	Precisión (Entrenamiento / Prueba / Validación)	Sensibilidad (Entrenamiento / Prueba / Validación)	Puntuaje F1 (Entrenamiento / Prueba / Validación)	Soporte (Entrenamiento / Prueba / Validación)
Barra de rotor rota	0.99 / 0.97 / 0.99	1.00 / 1.00 / 1.00	0.99 / 0.99 / 1.00	16200 / 5400 / 5400
Cortocircuito en estator	0.74 / 0.73 / 1.00	0.64 / 0.56 / 0.52	0.69 / 0.63 / 0.68	16200 / 5400 / 5400
Rodamientos contaminados	0.82 / 0.77 / 0.51	0.87 / 0.87 / 0.83	0.85 / 0.81 / 0.63	16200 / 5400 / 5400
Saludable	0.76 / 0.73 / 0.24	0.79 / 0.75 / 0.20	0.78 / 0.74 / 0.22	32400 / 10800 / 5400
<i>accuracy</i>	-	-	0.82 / 0.79 / 0.64	81000 / 27000 / 21600
<i>weighted avg</i>	0.83 / 0.80 / 0.69	0.82 / 0.79 / 0.64	0.83 / 0.79 / 0.63	81000 / 27000 / 21600

4.5 ASPECTOS RELEVANTES EN EL ANÁLISIS EXPERIMENTAL

Durante la fase experimental, se observó que el modelo *Random Forest* logra mantener un rendimiento elevado siempre que los datos de entrenamiento y prueba procedan del mismo régimen de trabajo para el sistema motor-bomba. Sin embargo, el desempeño del modelo presenta una disminución abrupta en precisión cuando datos adquiridos proceden de otros regímenes de trabajos. Este comportamiento sugiere la existencia de un fenómeno conocido como desplazamiento de dominio intra-clase (*intra-class domain shift*) donde instancias de una misma clase nominal, que en este caso representan el estado de operación saludable del motor, tienen variaciones sutiles pero relevantes en su distribución estadística. Se conoce que estas diferencias pueden deberse a múltiples factores como diferencias en la carga mecánica del motor, ruido electrónico, o incluso cambios en la calibración de los sensores. El modelo *Random Forest* es altamente sensible a tales variaciones, ya que basa sus decisiones en umbrales construidos sobre la distribución exacta de los datos vistos durante el entrenamiento. En este caso, *Random Forest* enfoca la decisión discriminante en las características espectrales y las medidas estadísticas dentro de bandas de frecuencia específicas como la magnitud máxima, la media y la desviación estándar en intervalos de 100 Hz (por ejemplo: *band_9700_9800_max_magnitude*, *band_7400_7500_mean_magnitude* y *band_4300_4400_std_magnitude*, entre otras). Además, en cuanto a relevancia, más del 95% de las variables se asignaron exclusivamente al campo de la frecuencia. Por otro lado, las propiedades tradicionales del dominio temporal como la media global o curtosis, exhibieron una importancia considerablemente inferior para la decisión final del modelo. Este resultado es técnicamente coherente ya que los fallos en los motores eléctricos suelen manifestarse en modulaciones de alta frecuencia, armónicos, o componentes específicas del espectro de corriente, para rangos específicos de frecuencia según el tipo de fallo. En este sentido, el análisis por bandas permite aislar y detectar estos patrones característicos mientras que las métricas globales del dominio del tiempo tienden a promediar la señal y en ocasiones no capturan adecuadamente los detalles espectrales distintivos de cada condición de operación. Por otro lado, los resultados muestran que el modelo AE+CNN es capaz de aprender y reproducir patrones característicos en señales de corriente para la detección de fallos en motores eléctricos, pero su desempeño solo es elevado ante condiciones de operación con patrones bien definidos. Ambos modelos, *Random Forest* y AE+CNN, presentan limitaciones importantes en su capacidad de generalización, especialmente frente a cambios en el reglaje del motor. Estas observaciones subrayan la importancia de incorporar mayor diversidad de datos en el entrenamiento, aplicar estrategias de regularización más robustas y explorar

técnicas de adaptación de dominio para construir sistemas más confiables y adaptables en contextos reales de operación industrial.

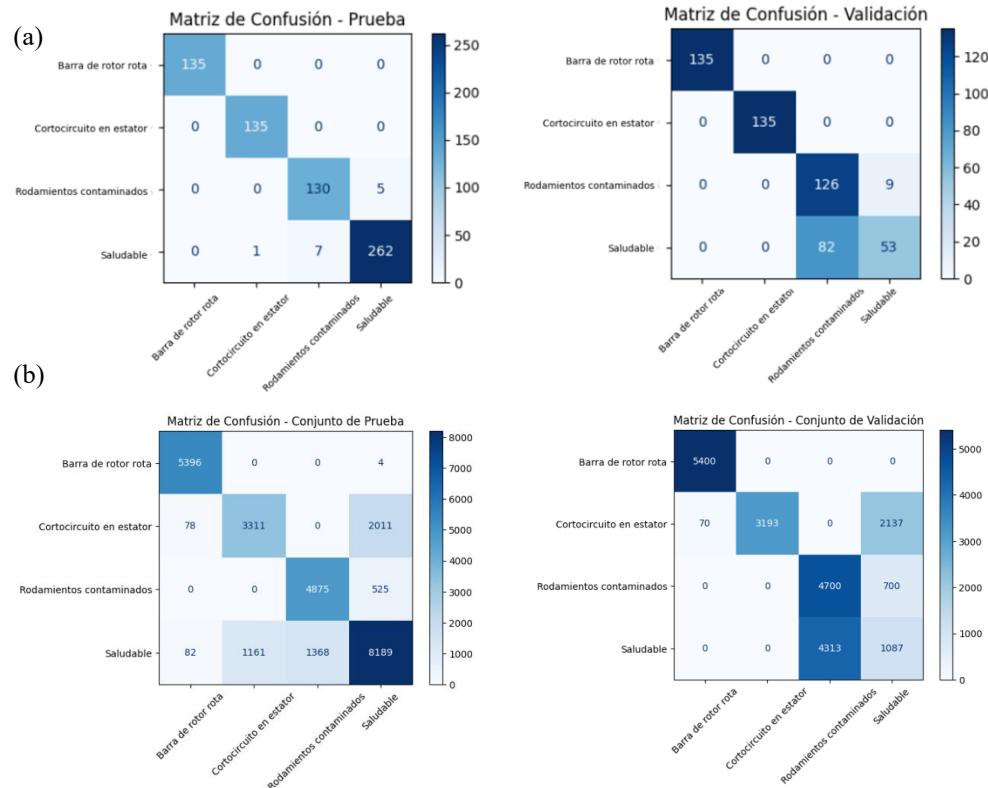


Figura 8

Matrices de confusión para etapas de prueba y validación obtenidas en el escenario 4: (a) Random Forest, (b) AE+CNN.

6.- CONCLUSIONES

En el presente trabajo se analizó la viabilidad de *Random Forest* y *AE+CNN* para detectar fallas operativas en motores eléctricos de jaula de ardilla, considerando exclusivamente señales de corriente. Los resultados obtenidos refuerzan el enfoque adoptado, y confirman que trabajar en el dominio de la frecuencia proporciona mayor capacidad discriminante en vista de detectar los fallos eléctricos y mecánicos que tienen lugar en los motores eléctricos de inducción. Aunque los resultados alcanzados son alentadores, se evidencia un impacto negativo del fenómeno de desplazamiento de dominio intra-clase relacionado a diferencias físicas en la alineación entre motor y carga. Por tanto, en vista de futuras investigaciones, se hace necesario realizar experimentos controlados donde se varíe explícitamente la configuración motor-bomba para desarrollar estrategias de normalización específicas o incluso etiquetado por configuración. Se recomienda, además, análisis adicionales utilizando señales de vibración y señales de corriente por fase. Aunque nuestro trabajo se centra exclusivamente en aprovechar las señales de corriente, los resultados sugieren que dicha variable puede no ser suficiente para capturar ciertos fallos y distinguir entre estados saludables con alta variabilidad. El análisis conjunto de señales de vibración y corriente permitiría mejorar la capacidad de generalización de los modelos y aportar información complementaria útil para la clasificación.

REFERENCIAS

1. Bahgat, B. H., Elhay, E. A., & Elkholy, M. M. (2024). Advanced fault detection technique of three phase induction motor: Comprehensive review. *Discover Electronics*, 1(1), 9.

2. Bazan, G. H., Goedtel, A., Duque-Perez, O., & Morinigo-Sotelo, D. (2021). Multi-fault diagnosis in three-phase induction motors using data optimization and machine learning techniques. *Electronics*, 10(12), 1462.
3. Sheikh, M. A., Bakhsh, S. T., Irfan, M., Nor, N. B. M., & Nowakowski, G. (2022). A review to diagnose faults related to three-phase industrial induction motors. *Journal of Failure Analysis and prevention*, 22(4), 1546-1557.
4. Murillo Oviedo, J. P., Herrera Fernández, F. B., & León Viltre, L. T. (2019). Modelado de la saturación en un sistema de generación eólica basado en DFIG. *Ingeniería Electrónica, Automática y Comunicaciones*, 40(2), 76-85.
5. Estévez-Rodríguez, J. E., Bernal-de Lázaro, JM. (2019). Análisis de los rodamientos usados en electro-ventiladores del sistema de refrigeración de motores Hyundai. *Ingeniería Mecánica*, 22(2), 85-91.
6. Vázquez Seisdedos, L., Trujillo Codorniu, R. A., Llosas Albuerne, Y., & Díaz Martínez, D. (2014). Método para detección de estados estacionarios: aplicación a unidades de generación eléctrica. *Ingeniería Electrónica, Automática y Comunicaciones*, 35(2), 45-61.
7. Hussain, R., Saleh, M. A., & Refaat, S. S. (2025). Various Faults Classification of Industrial Application of Induction Motors Using Supervised Machine Learning: A Comprehensive Review. *IEEE Access*.
8. Thomas, K., Rahman, A., Rohouma, W., Ahamed, M. F., Shafi, F. B., Nahiduzzaman, M., & Khandakar, A. (2025). Comprehensive fault diagnosis of three-phase induction motors using synchronized multi-sensor data collection. *Scientific Data*, 12(1), 1468.
9. Sonje, D. M., & Munje, R. (2025). Simultaneous Bearing Faults Detection in Three Phase Induction Motor Based on Feature Fusion Method and Random Forest Algorithm. *Journal of Operation and Automation in Power Engineering*, 13(4), 269-276.
10. Saxena, A., Kumar, R., Rawat, A. K., Majid, M., Singh, J., Devakirubakaran, S., & Singh, G. K. (2023). Abnormal Health Monitoring and Assessment of a Three-Phase Induction Motor Using a Supervised CNN-RNN-Based Machine Learning Algorithm. *Mathematical Problems in Engineering*, 2023(1), 1264345.
11. Sanchez, O. D., Martinez-Soltero, G., Alvarez, J. G., & Alanis, A. Y. (2023). Real-time neural classifiers for sensor faults in three phase induction motors. *IEEE Access*, 11, 19657-19668.
12. Bruinsma, S., Geertsma, R., Loendersloot, R., & Tinga, T. (2024). NLN-EMP - Motor Current and Vibration Monitoring Dataset for various Faults in an E-motor-driven Centrifugal Pump, *Data in brief*, 52, 109987.
13. Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning* (Vol. 1). MIT Press, Cambridge, MA, USA.
14. Zhang, C., Bengio, S., Hardt, M., Recht, B., & Vinyals, O. (2021). Understanding deep learning (still) requires rethinking generalization. *Communications of the ACM*, 64(3), 107-115.
15. Bengio, Y., Courville, C., & Vincent, P. (2013). Representation learning: A review and new perspectives. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 35(8), 1798-1828.
16. Toma, R. N., Piltan, F., & Kim, J.-M. (2021). Toma, R. N., Piltan, F., & Kim, J. M. (2021). A deep autoencoder-based convolution neural network framework for bearing fault classification in induction motors. *Sensors*, 21(24), 8453.

CONFLICTO DE INTERESES

Ninguno de los autores manifestó la existencia de posibles conflictos de intereses que debieran ser declarados en relación con este artículo. Los autores agradecen el apoyo docente del Master de Inteligencia Artificial de la Universidad Internacional de La Rioja (UNIR), España. Los autores agradecen también el apoyo financiero de FAPERJ, Fundação Carlos Chagas Filho de Amparo à Pesquisa do Estado do Rio de Janeiro; Brasil. Bolsa Pós-Doutorado_Sênior (PDS) Edital-FAPERJ Nº_18_2024.

CONTRIBUCIONES DE LOS AUTORES

Guillermo León Zapata Álvarez: Curación de datos, Conceptualización, Investigación, Metodología, Análisis Formal, Software, Validación – Verificación y Redacción.

Rafael Andrade Cortegoso: Curación de datos, Conceptualización, Investigación, Metodología, Análisis Formal, Software, Validación – Verificación y Redacción.

José Manuel Bernal de Lázaro: Conceptualización, Metodología, Análisis Formal, Validación – Verificación.

AUTORES

Guillermo León Zapata Álvarez, Ingeniero Mecatrónico (2005) y Especialista en Inteligencia Artificial (2024) de la Universidad Autónoma de Occidente de Cali, Colombia, con 17 años de experiencia en el campo de la automatización industrial, enfocado en sistemas de control distribuido y aplicaciones de variadores de velocidad de baja tensión, es un

profesional con intereses técnicos orientados al análisis de datos, la automatización y la aplicación de tecnologías emergentes en entornos industriales. Actualmente cursa el Máster en Inteligencia Artificial de la Universidad Internacional de La Rioja (UNIR), donde profundiza en aprendizaje automático, visión artificial y sistemas inteligentes. Complementa su formación con proyectos prácticos enfocados en el desarrollo de soluciones basadas en IA para la optimización de procesos y el apoyo a la toma de decisiones. Correo: glzapata82@gmail.com, <https://orcid.org/0009-0006-9766-3442>

Rafael Andrade Cortegoso, Ingeniero Técnico Naval en la especialidad de Propulsión y Servicios (2002) por la Universidad de A Coruña (UDC), España, con 21 años de experiencia en campos como mantenimiento mecánico industrial, construcción naval y la planificación integrada. Con una sólida orientación técnica y especial interés en la integración de tecnologías digitales para la mejora de procesos y la automatización inteligente. Actualmente cursa el Máster en Inteligencia Artificial y el Curso Universitario Avanzado en Inteligencia Artificial y Data Engineering de la Universidad Internacional de La Rioja (UNIR), donde se especializa en aprendizaje profundo, analítica avanzada y sistemas basados en datos. Su desarrollo académico se complementa con proyectos aplicados centrados en la implementación de soluciones de IA que impulsen la eficiencia operativa y la innovación tecnológica en diversos entornos industriales. Correo: andradecor@gmail.com, <https://orcid.org/0006-3040-0009-0002>

José Manuel Bernal de Lázaro, Doctor en Ciencias Técnicas (PhD, 2016), Máster en Modelación Matemática (MSc, 2014) e Ingeniero en Automática (2010) por la Universidad Politécnica de La Habana (CUJAE), Cuba. Actualmente es docente en la Escuela Superior de Ingeniería y Tecnología (UNIR), España. Ha sido profesor en la CUJAE (2012-2025) y actualmente es Post-doctorante Senior de FAPERJ en el Instituto Politécnico da Universidad do Estado de Rio de Janeiro (IPRJ-UERJ). Sus principales temas de investigación incluyen el diagnóstico de fallos, la inteligencia computacional y la automatización de procesos. Correo: josemanuel.bernal-externo@unir.net , <https://orcid.org/0000-0002-2797-0205>



Esta revista se publica bajo una [Licencia Creative Commons Atribución-No Comercial-Sin Derivar 4.0 Internacional](https://creativecommons.org/licenses/by-nc-nd/4.0/)